

Sveučilište u Zagrebu

Filozofski fakultet

Odsjek za psihologiju

**Stavovi prema statistici, statističko rezoniranje i njihov  
međuodnos**

Diplomski rad

Ivan Gorski

Mentor: Prof. dr. sc. Vesna Buško

Zagreb, 2017

## Sadržaj

Uvod .....	1
Statistička pismenost, rezoniranje i razmišljanje.....	2
Ispitivanje statističkog rezoniranja i zabluda u statističkom rezoniranju .....	4
Model studentskih stavova prema statistici .....	5
Cilj, istraživački problemi i hipoteze.....	9
Metodologija.....	10
Metoda i postupak .....	10
Instrumenti.....	11
Rezultati.....	14
Rasprava .....	20
Metodološka ograničenja i smjernice za buduća istraživanja .....	25
Zaključak .....	26
Literatura .....	28

### **Sažetak - Stavovi prema statistici, statističko rezoniranje i njihov međuodnos**

Obrada brojčanih podataka s ciljem jasnijeg prikazivanja istih naziva se statistika (Petz, 2007). Znanje statistike omogućuje donošenje boljih odluka zbog čega se ono sve više traži u praksi i znanosti. Zbog toga se nastava statistike sve više proučava te je razvijen model stavova prema statistici (SATS-M; Ramirez, Schau i Emmioğlu, 2012). Cilj ovog istraživanja, postavljen u skladu s tim modelom, bio je ispitati kakve stavove prema statistici imaju studentice i studenti različitih studijskih smjerova te kakva je povezanost tih stavova, spola i prijašnjih iskustava u sličnim područjima sa statističkom pismenosti, rezoniranjem i razmišljanjem kao i s bihevioralnim namjerama za buduće bavljenje statistikom. Istraživanje je provedeno na studentima prve godine psihologije, geografije i sociologije Sveučilišta u Zagrebu ( $N=144$ ). Iako studenti smatraju da je statistika teška, u prosjeku su dobiveni pozitivni stavovi prema statistici. Hipoteze su djelomično potvrđene, a pokazano je kako se studenti razlikuju u stavovima i to u smjeru da studenti pokazuju više interesa prema statistici te smatraju da je statistika korisnija nego studentice. Posebno su se izdvojile studentice psihologije koje ulažu više truda za savladavanje statistike od svih ostalih studenata. Kao jedini značajan prediktor statističkog rezoniranja pokazao se spol, a jedini značajni prediktor namjere upisivanja izbornog kolegija koji ima veze sa statistikom je percepcija vrijednosti statistike. Rezultati ovog istraživanja ukazuju na potrebu za radom na poboljšavanju stavova prema statistici kako bi studenti češće koristili statistiku u svojoj akademskoj i poslovnoj budućnosti.

Ključne riječi: statistika, statističko rezoniranje, stavovi prema statistici

### **Summary - Attitudes toward statistics, statistical reasoning and their relationship**

#### **Sažetak**

Data analysis with the aim of making the data clearer is called statistics. Analysing data with a purpose of making them clearer is called statistics (Petz, 2007). Statistical knowledge is more and more sought for both in practice and science since it helps in making better, more informed decisions. This is the reason why statistical courses have becoming a topic of research and why Ramirez, Schau and Emmioğlu (2012) developed a model of attitudes toward statistics. The aim of this study, pursuant to said model, was to test student's attitudes toward statistics and to explore attitudes towards statistics and to test the relationship between statistics attitudes, student characteristics and previous achievement-related experiences with course outcomes as well as behavioural intentions of prospective use of statistics. The research was conducted on the sample of first year psychology, sociology and geography students from the University of Zagreb, Croatia ( $N=144$ ). Although students perceive statistics as hard, on average they have positive attitudes towards it. Hypotheses are partly confirmed, and it has been shown that male students express more interest toward statistics and that they think statistics is more useful, compared to their female colleagues. Female psychology students make more effort in statistics courses than any other group of students. Sex was the only significant predictor of statistical reasoning and perception of statistical value was the only significant predictor of intent to participate in other statistical courses. The results of this research imply that students might use more statistics in their prospective academic and professional careers if we work on their attitudes toward statistics.

Key words: statistics, statistical reasoning, attitudes toward statistics

## Uvod

Obrada brojčanih podataka s ciljem jasnijeg prikazivanja istih naziva se statistika (Petz, 2007). Teško da se može zamisliti ijedna grana znanosti u suvremenom svijetu koja se barem djelomično ne oslanja na nju, odnosno ne koristi statističke analize. Znanje statistike omogućuje donošenje informiranih odluka, a ne onih koje su temeljene na intuiciji ili anegdotalnim podacima. U skladu s tim, statistički kolegiji su sastavan dio mnogih studijskih programa na fakultetima u svijetu (Blumberg, 2001), a i u Hrvatskoj. Potreba za stručnjacima sa znanjem statistike danas se sve više prepoznaje, kako u znanosti (Garfield, Chance i Snell, 2001), tako i u praksi (Bakker, 2004). U današnje vrijeme kada su informacije svima dostupne, a organizacije moraju biti brže i bolje, potreba za obradom tih podataka važnija je nego ikad prije (Hair, Black, Babin i Anderson, 2009). Istraživanje koje je proveo PricewaterhouseCoopers (PWC) pokazuje da 89% velikih firmi koristi ili planira koristiti podatke kako bi donijeli odluke (Guenole, Ferrar i Feinzig, 2017). U skladu s tim, prema nedavno objavljenom članku posao statističara smatra se najboljim poslom 2017. godine prema brojnim kriterijima, od zapošljivosti do visine plaće (CareerCast.com, 2017). Zbog svega navedenog, potrebno je pratiti trendove u obrazovanju iz statistike te opremiti studente statističkim znanjima kako bi bili adekvatno pripremljeni za posao koji će obavljati, bilo u znanosti, bilo u praksi.

Kako bi se to postiglo, prema Garfieldu, Hoggu, Schau i Whittinghillu (2002), statistički kolegiji bi trebali biti središte visokoškolskog obrazovanja. Kao univerzalni ishodi za studente na statističkim kolegijima smatraju se razvijanje statističke pismenosti (engl. *statistical literacy*), statističkog rezoniranja (engl. *statistical reasoning*) i statističkog razmišljanja (engl. *statistical thinking*) (Garfield i sur., 2002). Dosadašnja istraživanja pokazala su kako je usvajanje relevantnih znanja iz statistike otežano zbog čestih negativnih stavova prema statistici te straha od nje kod studenata (npr. Ruggeri, Dempster i Hanna, 2011). Strah od statistike je izražen kod većine studenata (Birenbaum i Eylath, 1994, prema Baloglu, 2003), a što je on veći, to su stavovi prema statistici negativniji (Macher, Paechter, Papousek i Ruggeri, 2012). Zbog toga je u ovom istraživanju naglasak stavljen na statističku pismenost, rezoniranje i razmišljanje, stavove prema statistici te njihov međudodnos.

### *Statistička pismenost, rezoniranje i razmišljanje*

Statistička pismenost, rezoniranje i razmišljanje tri su najčešće navođena ishoda na statističkim kolegijima, a svaki od ovih ishoda odgovara barem jednoj razini u Bloomovoj taksonomiji (Garfield i Ben-Zvi, 2008), najčešće korištenim načinom definiranja ishoda učenja koji ishode klasificira prema razinama apstrakcije potrebnima za njihovo savladavanje (Anderson i sur., 2001), a detaljnije je prikazana u tablici 1.

Statistička pismenost je poznavanje osnovnih koncepata, vokabulara i simbola koji se koriste u statistici. Prema Garfieldu i Ben-Zviju (2008) statistička pismenost najniža je razina poznavanja statistike, a u Bloomovoj taksonomiji odgovara razini ishoda *znanje*.

Statističko rezoniranje je način na koji ljudi rasuđuju o statističkim idejama i pronalaze značenje u statističkim informacijama. Prema Petzu (2005, str. 417) rezoniranje ili rasuđivanje općenito je „misaoni proces pri rješavanju problemne situacije; uključuje formiranje i sustavno provjeravanje hipoteza u potrazi za logičnim rješenjem problemne situacije.“ Statističko rezoniranje uključuje sposobnost točne interpretacije rezultata, prikaza rezultata ili sažetaka podataka te razumijevanje cjelokupnog procesa statističke analize (Garfield, delMas i Chance, 2003). Prema Garfieldu i Ben-Zviju (2008) statističko rezoniranje u Bloomovoj taksonomiji odgovara *razumijevanju*.

Statističko razmišljanje uključuje razumijevanje razloga zbog čega i kako su statističke analize provedene: to je način na koji misle profesionalni statističari (Garfield i Ben-Zvi, 2008). Statističko razmišljanje je spoj ostalih kategorija (*primjena, analiza, evaluacija i sinteza*) iz Bloomove taksonomije te prema tome predstavlja najvišu razinu statističkog rezoniranja.

*Tablica 1*

Prikaz ishoda učenja prema Bloomovoj taksonomiji (prilagođeno iz Anderson i sur., 2001).

Razina ishoda	Objašnjenje
Znanje	mogućnost reprodukcije naučenog u izvornom obliku
Razumijevanje	uočavanje i povezivanje glavnih ideja, opisivanje tijeka događaja i procesa
Primjena	rješavanje problema u novoj situaciji primjenom stečenog znanja i pravila na nov način
Analiza	rašćlanjivanje informacija kako bi se utvrdili uzroci i posljedice, izveli dokazi i zaključci i podržale generalizacije
Evalvacija	vrednovanje i kritički odnos prema informacijama, mogućnost procjene valjanosti ideja ili kvalitete uratka
Sinteza	mogućnost stvaranja novih ideja, rješenja, sintetiziranje bitnoga, uočavanje novih obrazaca

Statistički kolegiji u svijetu previše su usmjereni na statističku pismenost, dok kod studenata rijetko razvijaju načine kako i kada provoditi različite statističke metode te kako interpretirati rezultate statističkih testova (Mallows, 1998).

Ljudi općenito smatraju statističko razmišljanje izrazito teškim (Kahneman i Tversky, 1982), a greške u statističkom razmišljanju ne događaju se samo sudionicima u istraživanjima, već i stručnjacima (Tversky i Kahneman, 1974). Jedan od razloga zbog kojih studenti imaju problema sa statistikom je potrebno predznanje matematike. Primjerice, kod izračuna aritmetičke sredine moguće je dobiti rezultat koji ne postoji među sirovim podacima, što za studente slabije upoznate s matematičkim konceptima može biti zbunjujuće (Garfield i Ben-Zvi, 2008). Nadalje, iako se statistika temelji na stvarnim podacima, dio njenog sadržaja zahtijeva razmišljanje izvan uobičajenih okvira realnosti (Sfrad, 2000). Dosad je identificirano nekoliko zabluda u statističkom rezoniranju i razmišljanju (Garfield i Ben-Zvi, 2008):

*Zabluda o središnjim vrijednostima* su one u kojima osoba ne razlikuje aritmetičku sredinu i centralnu vrijednost, ne zna ih izračunati ili misli da se grupe uspoređuju isključivo prema središnjim vrijednostima, ne uzimajući u obzir mjere raspršenja.

*Orijentiranost na ishod* je prema Konoldu (1989) intuitivni model vjerojatnosti prema kojem osoba stvara binarne prosudbe o tome što se treba dogoditi u jednom izoliranom slučaju, a ne gleda velik broj istih slučajeva. Na primjer, procijenjeno je da KHL Tapiri imaju 80% šanse pobijediti KHL Medveščak, ako KHL Tapiri pobijede u osam od deset utakmica osoba će često misliti kako je to bila loša prognoza jer misli da bi klub koji ima 80% šanse pobijediti trebao pobijediti u svakoj utakmici.

Zabluda je i da su *dobri uzorci* samo oni koji predstavljaju većinu populacije, neovisno o načinu prikupljanja ili veličini uzorka.

*Zakon malih brojeva* kaže da ljudi misle kako će i mali uzorak iz populacije odgovarati populaciji.

*Zabluda o reprezentativnosti* kaže kako ljudi računaju vjerojatnost uzorka na temelju toga koliko precizno odgovara populaciji. Na primjer, ako je novčić bačen deset puta i u pet slučajeva ishod je bila glava, a u pet pismo, osoba će smatrati takav slučaj vjerojatnijim od onog gdje bi u osam slučajeva ishod bio pismo, a u preostala dva glava (Tversky, Slović i Kahneman, 1990). S druge strane, Lecoutre (1992) je pokazao da postoji tendencija izjednačavanja vjerojatnosti različito vjerojatnih događaja kod nekih ljudi. Osobe koje pokazuju ovu tendenciju smatraju kako je u igri s kockicama Jamb jednaka vjerojatnost dobiti četiri ista broja na kockicama (5, 5, 5, 5), kao i četiri broja za redom (4, 5, 3, 2).

Još jedna uočena zabluda je kada ljudi *kovariranje događaja tumače kao uzročno-posljedične veze* (Garfield, 2003).

*Ispitivanje statističkog rezoniranja i zabluda u statističkom rezoniranju*

Kako bi se ispitalo jesu li navedene zabluda prisutne kod studenata te jesu li ispunjeni ciljevi kolegija potrebno je provoditi provjere znanja. Kod tradicionalnih metoda ispitivanja znanja

od studenata se traži da naprave neki matematički izračun ili da se dosjete specifične informacije (Garfield i Ben-Zvi, 2008). Takav način ispitivanja je za profesora jednostavniji budući da je tako lakše sastaviti pitanja i napraviti obrazac za bodovanje. Međutim te metode ispitivanja znanja su preuske te ne promiču uspješne metode učenja zbog čega ih je potrebno promijeniti. One ne otkrivaju kako i koliko studenti razumiju statističke ideje niti provjeravaju jesu li studenti u mogućnosti primijeniti ta znanja na stvarne probleme (Garfield i Ben-Zvi, 2008). S druge strane, pitanja koja bi provjeravala statističko rezoniranje i razmišljanje teže je sastaviti i potrebno je više vremena za njihovo ispravljanje. Također, u praksi studenti često imaju problema već kod ispitivanja statističke pismenosti, što dodatno obeshrabruje profesore u sastavljanju zahtjevnijih ispita. Zbog toga je Garfield (2003) razvio *Test statističkog rezoniranja* (engl. *The Statistical Reasoning Assessment, SRA*) na kojem se mogu dobiti rezultati na pojedinim subskalama za različite vrste statističkog rezoniranja. Također je važno naglasiti kako SRA sadrži pitanja koja se, osim na statističko rezoniranje, odnose i na statističku pismenost i na statističko razmišljanje (Ben-Zvi i Garfield, 2004).

#### *Model studentskih stavova prema statistici*

Koliko ćemo gradiva naučiti, kakve ćemo kognitivne procese koristiti i koje ćemo kolegije na fakultetu odabrati uvelike ovisi i o našoj motivaciji (Garner i sur., 1991, prema Vizek Vidović, Rijavec, Vlahović-Štetić i Miljković, 2003). Motivacija je stanje u kojem smo „iznutra“ pobuđeni nekim potrebama, porivima, željama ili motivima na određeno ponašanje usmjereno prema postizanju nekog cilja (Petz, 2005). Teorijama motivacije nastoji se objasniti kako pojedinac odabire aktivnosti, koliko je ustrajan u njima te koliko će u njima biti uspješan (Vizek Vidović i sur., 2003). Jedan suvremeni okvir koji pokušava dati odgovore na ta pitanja je *teorija očekivanja i vrijednosti* (Wigfield i Eccles, 2000). Prema toj teoriji na ponašanje u akademskim situacijama utječu *očekivanja pojedinca, vrijednosti i kontekstualni utjecaji*. Prema Wingfieldu i Eccles (2000) *očekivanja pojedinca* o uspjehu su učenička ili studentska uvjerenja o tome koliko će biti dobri u sadašnjim ili budućim zadacima. *Vrijednosti* su uvjerenja o razlozima zbog kojih se učenik uključuje u neku aktivnost. *Kontekstualni utjecaj* obuhvaća varijable poput inteligencije, osobina ličnosti, spola i dobi. U skladu s navedenom teorijom, Ramirez, Schau i Emmioğlu (2012) razvili su



model studentskih stavova prema statistici (SATS-M). Prema SATS-M postoje tri opća konstrukta koji predviđaju ishode statističkih kolegija. Osim statističke pismenosti rezoniranja i razmišljanja kao ishodi statističkih kolegija mogu se smatrati i ponašanja studenata nakon tih kolegija, od odabira izbornih kolegija do odabira posla. U ovom istraživanju, kao jedna mjera ishoda statističkih kolegija, korišteno je *statističko rezoniranje studenata* mjereno SRA testom. Kao druga mjera ishoda korištena mjerena je *namjera upisivanja izbornih kolegija koji imaju veze sa statistikom*, ona predstavlja bihevioralnu namjeru, a ona je najbolji prediktor budućeg ponašanja (Ajzen i Fishbein, 1977).

Konstrukti koji predviđaju statističke ishode prema SATS-M su *stavovi prema statistici*, *prijašnja iskustva u sličnim područjima* i *studentske karakteristike*.

U model su uključene komponente vrijednosti iz Ecclesine teorije koje autori nazivaju *stavovi prema statistici*. Prema Petzu (2005, str. 465) stav je „stečena, relativno trajna i stabilna organizacija pozitivnih ili negativnih emocija, vrednovanja i reagiranja prema nekom objektu“. U ovom istraživanju taj objekt je statistika. Već je iz definicije vidljivo da se stav sastoji od tri komponente: kognitivne, emocionalne i bihevioralne. Kognitivna komponenta uključuje *uvjerenja* o objektu stava; *emocije* i *osjećaji* potaknuti objektom stava dio su afektivne komponente, a bihevioralna komponenta obuhvaća *akcije* usmjerene prema objektu stava kao i *bihevioralne namjere* (Hewstone i Stroebe, 2003)

Schau (2003) dodatno dijeli stavove prema statistici na šest faktora: *afekt*, *kognitivna kompetencija*, *vrijednost*, *težina*, *interes* i *trud*. *Afekt* se odnosi na studentske osjećaje prema statistici. *Kognitivne kompetencije* su studentski stavovi o njihovim intelektualnim sposobnostima za razumijevanje statistike. *Vrijednost* je faktor koji se odnosi na studentska uvjerenja o korisnosti i vrijednosti statistike za njihovu profesionalnu budućnost. *Težina* je percepcija studenata o tome koliko je statistika težak predmet. *Interes* je razina interesa osobe za statistiku, a *trud* je količina vremena koje je student uložio u učenje statistike (Schau, 2003). Faktori uključeni u ovaj model uglavnom obuhvaćaju kognitivne i emocionalne komponente stava, a *trud* je akcijski dio bihevioralne komponente. Bihevioralne namjere nisu uključene u ovaj model kao dijelovi stava prema statistici, već kao ishod.

Meta analiza studentskih stavova prema statistici je pokazala njihovu važnost u objašnjavanju uspjeha u statistici (Emmioğlu i Çapa-Aydin, 2011) u smjeru da studenti s pozitivnijim stavovima postižu bolji uspjeh od onih s negativnijim stavovima.

Studentske karakteristike i prijašnja iskustva u sličnim područjima odgovaraju kontekstualnim utjecajima iz Ecclesine teorije. U studentske karakteristike se najčešće ubrajaju spol, nacionalnost i dob. Međutim, autori navode kako se i druge karakteristike mogu uključiti u ovaj model (Ramirez i sur., 2012).

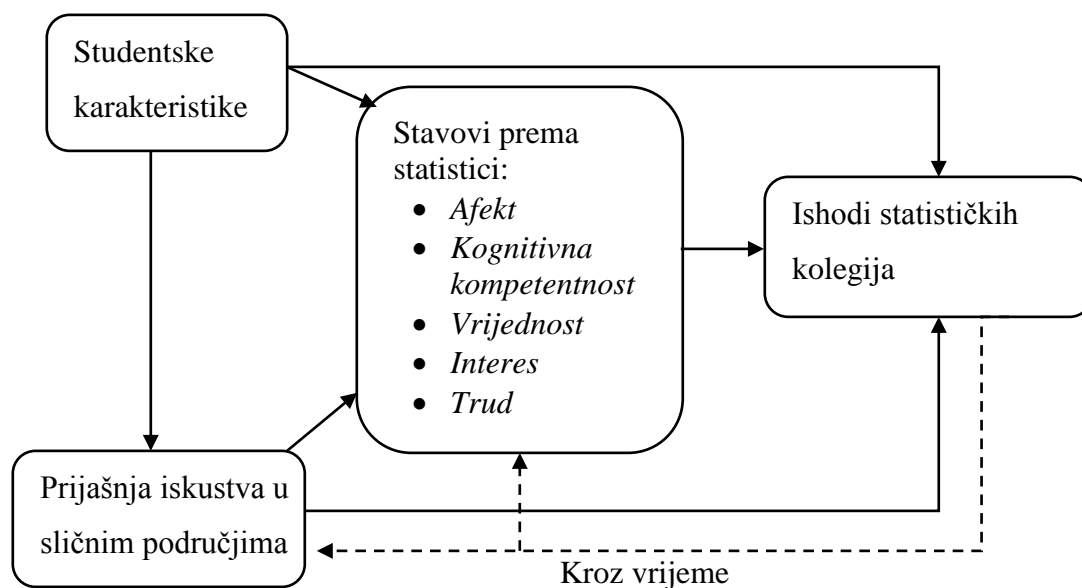
Kod stavova prema statistici su pronađene razlike obzirom na neke studentske karakteristike. Prema Ramirez i suradnicima (2012) nije moguće sa sigurnošću tvrditi postoje li spolne razlike u stavovima jer otprilike polovica studija nalazi značajne razlike u korist muškaraca, dok druga polovica ne nalazi razlike. Ruggeri i suradnici (2008) pronašli su razlike u stavovima prema statistici ovisno o nacionalnosti studenata. Ramirez i suradnici (2012) navode kako su pronašli tri istraživanja koja su ispitivala povezanost s dobi, međutim smjer veza se u tim istraživanjima razlikovao. Zbog toga zaključuju kako je potrebno provesti dodatna istraživanja o povezanosti s dobi. Također su pronađene razlike u stavovima obzirom na područje studija te je Evans (2007) pokazao kako studenti sociologije imaju pozitivnije stavove nego studenti psihologije. Prema mišljenju autora puno studenata bira studij psihologije kada ne znaju koji studij odabrati zbog čega imaju negativnije stavove (Evans, 2007).

U drugim istraživanjima, nevezanim uz ovaj model, kao značajan prediktor statističkih ishoda pokazale su se osobine ličnosti savjesnosti i ekstraverzije (Furnham i Chamorro-Premuzic, 2003). U istom istraživanju je dobiveno kako inteligencija objašnjava tek 3% varijance uspjeha na ispitu.

U konstrukt prijašnjih iskustava sa sličnim područjima najčešće su uključene varijable srednjoškolskih ocjena (najčešće iz matematike) i duljine iskustva (s matematikom i statistikom). Studenti s više iskustva i s boljim prijašnjim uspjehom postižu bolje rezultate na statističkim kolegijima (npr. Carlson i Winqusit, 2011; Chiesi i Primi, 2010). Prijašnja

iskustva su povezana i sa statističkim rezoniranjem, međutim te su korelacije uglavnom male (npr. Tempelaar, 2004).

Na slici 1 prikazan je model stavova prema statistici (SATS-M) koji odgovara još nekim modernim teorijama (Ramirez i sur., 2012). Bandurina (1986) socijalno-kognitivna teorija kaže da je motivacija cilju usmjereno ponašanje koje se javlja pod utjecajem očekivanja o ishodima akcija (*vrijednost*) i percepciji samoeфикаsnosti za izvođenje tih akcija (što odgovara *kognitivnim kompetencijama*). SATS-M odgovara i teoriji samodeterminacije (Deci i Ryan, 2010) koja kaže da će na motivaciju utjecati način na koji se studenti osjećaju (*afekt*), pokazivanja *interesa* i mišljenja o *vrijednosti* statistike.



Slika 1: Prikaz modela studentskih stavova prema statistici (SATS-M, preuzeto iz Schau, 2003)

Zaključno, ovo istraživanje želi provjeriti stabilnost dosadašnjih nalaza dobivenih u provjeravanju modela stavova prema statistici kod hrvatskih studenata te doći do novih saznanja kojima se dosadašnja istraživanja nisu bavila.

Na mnogim studijskim programima postoji kolegij statistike, međutim sama korist statistike u budućem radu te opseg gradiva statistike se razlikuje od studija do studija. Nadalje, različite studije upisuju studenti s različitim prethodnim iskustvom sa statistikom i sličnim

područjima. Zbog toga možemo očekivati razlike u stavovima prema statistici obzirom na područje studija. Kao što je već rečeno dio istraživanja pronalazi razlike u stavovima prema statistici obzirom na spol u smjeru da studenti imaju pozitivnije stavove. Uz to, dosadašnja istraživanja većinom su provjeravala povezanost stavova prema statistici s uspjehom na kolegiju iz statistike, dok su tek rijetka gledala povezanost s validiranim mjerama statističkog rezoniranja, poput testa znanja korištenog u ovom istraživanju. Na kraju, dosadašnja istraživanja nisu istraživala povezanost s dugoročnim ishodima poput toga hoće li studenti upisati izborne kolegije koji imaju veze sa statistikom, niti su se previše oslanjala na relevantnu teoriju. U skladu s time postavljeni je cilj i problemi istraživanja.

### **Cilj, istraživački problemi i hipoteze**

Cilj ovog istraživanja je ispitati kakve stavove prema statistici imaju studentice i studenti različitih studijskih smjerova te kakva je povezanost tih stavova, spola i prijašnjih iskustava u sličnim područjima sa statističkom pismenosti, rezoniranjem i razmišljanjem kao i s bihevioralnim namjerama za buduće bavljenje statistikom.

U skladu s navedenim ciljevima postavljeni su sljedeći problemi i hipoteze:

1. Problem: Ispitati razlike u stavovima prema statistici (faktori: *afekt, trud, vrijednosti, kognitivna kompetencija, težina i interes*) obzirom na spol i studijsku grupu (psihologija, geografija i sociologija).

Hipoteza 1. Na svim faktorima stava prema statistici studenti će postići viši rezultat od studentica, a također postoje razlike na faktorima stavova prema statistici obzirom na područje studija. Ne očekuje se interakcija ovih varijabli.

2. Problem: Ispitati mogućnost predviđanja znanja iz statistike mjerenog ljestvicom točnog rezoniranja na temelju *spola* (kao varijable iz kategorije studentskih karakteristika), *samoprocjene znanja srednjoškolske matematike* i *prosječnog broja sati matematike u srednjoj školi* (kao mjera prijašnjih iskustava) i mjere stavova prema statistici (faktori: *afekt, trud, vrijednosti, kognitivna kompetencija, težina i interes*).

Hipoteza 2. Viši rezultat na subskali točnog rezoniranja imat će muškarci, studenti koji svoje *znanje srednjoškolske matematike* procjenjuju boljim, oni koji su imali više *sati matematike u srednjoj školi* te studenti koji postižu više rezultate na subskalama *afekta, truda, vrijednosti, kognitivne kompetencije, težine i interesa*.

3. Problem: Ispitati mogućnost predviđanja namjere upisivanja izbornih kolegija iz statistike na temelju spola (kao varijable iz kategorije studentskih karakteristika), *samoprocjene znanja srednjoškolske matematike* i *prosječnog broja sati matematike u srednjoj školi* (kao mjera prijašnjih iskustava) i mjere stavova prema statistici (faktori: *afekt, trud, vrijednosti, kognitivna kompetencija, težina i interes*).

Hipoteza 3. Studenti koji smatraju da će upisati izborni predmet koji ima veze sa statistikom procjenjivat će svoje znanje matematike boljim, imali su više sati matematike u srednjoj školi te postižu više rezultate na *subskalama afekta, truda, vrijednosti, kognitivne kompetencije, težine i interesa* nego studenti koji smatraju kako je mala vjerojatnost da će upisati izborni kolegij koji ima veze sa statistikom.

## **Metodologija**

### *Metoda i postupak*

Istraživanje je provedeno na studentima prve godine Sveučilišta u Zagrebu ( $N=144$ ) u travnju 2017. godine. U istraživanju su sudjelovale 92 studentice i 52 studenta. Prosječna dob sudionika je 19.8 ( $SD=1.81$ ) godina. Najviše studenata je bilo sa studija psihologije na Filozofskom fakultetu ( $n=85$ ), a zatim s geografije na Prirodoslovno matematičkom fakultetu ( $n=35$ ) i sa sociologije na Filozofskom fakulteta ( $n=24$ ). U tablici 2 prikazani su deskriptivni podaci ocjena studenata i studentica na različitim studijima, a u tablici se može vidjeti kako prosječna ocjena iz statistike iznosi 3.17, a oko polovice studenata sociologije nije položilo kolegij iz statistike. U rezultate istraživanja nije uvršten jedan student geografije jer nije odgovorio s ponuđenim odgovorima, već je ponudio svoje. Svi sudionici su odslušali uvodni kolegij statistike.

*Tablica 2*  
Prikaz prosječnih ocjena studenata iz statistike i iz cijelog studija (N=144)

	Svi	Studenti psihologije (n=85)		Studenti sociologije (n=24)		Studenti geografije (n=35)	
		M	Ž	M	Ž	M	Ž
<i>M</i> ocjene iz statistike (n)	3.17 (132)	2.81 (26)	3.32 (59)	4.00 (4)	2.78 (9)	3.22 (18)	3.13 (15)
<i>M</i> prosječne ocjene na cijelom studiju (n)	3.61 (135)	3.13 (24)	3.79 (57)	3.50 (6)	3.29 (14)	3.83 (18)	3.80 (15)

*Legenda:* Ocjena iz statistike=kod studenata psihologije i sociologije to je zaključena ocjena na kraju semestra, dok je kod studenata geografije to ocjena iz kolokvija; n=broj studenata

Sudionicima su podijeljeni upitnici u sklopu obavezne nastave. Najprije su sudionici dobili uputu gdje je navedeno kako je cilj istraživanja ispitati model stavova prema statistici. Naglašeno je kako je ispitivanje dobrovoljno i anonimno te da nema vremenskog ograničenja, a ispunjavanje traje oko 20 minuta. Sudionici su u uputi također zamoljeni da što iskrenije odgovaraju na pitanja. Prvo su rješavali upitnik o stavovima prema statistici (SATS-36) te na njegovom kraju odgovarali na dodatne čestice o studentskim karakteristikama i prijašnjem iskustvu u sličnim područjima. Na kraju su sudionici rješavali test statističkog rezoniranja (SRA).

### *Instrumenti*

S obzirom na to da je ovo prvo istraživanje ove vrste u Republici Hrvatskoj, bilo je potrebno prevesti upitnik stavova prema statistici (SATS-36) i test statističkog rezoniranja (SRA). U skladu sa suvremenim smjernicama o prevođenju i kulturalnoj prilagodbi inozemnih mjernih instrumenata (Van de Vijver i Tanzer, 2004), tri neovisna prevoditelja su prevela upitnik koji je potom provjeren u tzv. fokusnim grupama. Fokusnu grupu činilo je šest studenata od kojih su troje bili studenti psihologije, dvoje anglistike te jedan geografije. Na fokusnoj grupi su predloženi prijevodi prevedeni ponovo na engleski jezik te su odabrani najbolji prijevodi svih čestica. Fokusne grupe provedene su u prostorijama u vlasništvu istraživača.

Stavovi prema statistici u ovom istraživanju mjereni su pomoću *Upitnika stavova prema statistici* (engl. *Survey of Attitudes Toward Statistics-36*, SATS-36, Schau, Stevens, Dauphinee i Vecchio, 1995). Taj upitnik sastoji se od šest faktora, a faktori su: *afekt* („Sviđa mi se statistika“), *kognitivna kompetentnost* („Mogu naučiti statistiku“), *vrijednost* („Koristim statistiku u svakodnevnom životu“), *težina* („Statističke formule su lako razumljive“), *interes* („Zanima me korištenje statistike“) i *trud* („Učio sam marljivo za sve testove iz statistike“). Sudionici odgovaraju na svaku od 36 čestica koristeći Likertovu skalu sa sedam uporišnih točaka (1=“Uopće se ne slažem“, 4=“Niti se slažem niti se ne slažem“, 7=“U potpunosti se slažem“). Veći rezultat na upitniku označava pozitivniji stav. Nekoliko studija je pokazalo da ovaj upitnik dobiva zadovoljavajuće vrijednosti Cronbahovog alfe (od  $\alpha=.64-.81$  na subskali *težine* te od  $\alpha=.77-.90$  na ostalim subskalama, prema Ramirez i sur., 2012). U ovom istraživanju dobivene su sljedeće vrijednosti Cronbachovog alfe: *afekt* ( $\alpha=.79$ , 6 čestica), *kognitivna kompetentnost* ( $\alpha=.81$ , 6 čestica), *vrijednost* ( $\alpha=.78$ , 9 čestica), *težina* ( $\alpha=.61$ , 7 čestica), *interes* ( $\alpha=.82$ , 4 čestice) i *trud* ( $\alpha=.77$ , 4 čestice). Ukupan rezultat za pojedini aspekt stava (subskala) prikazan je kao prosječna vrijednost jednostavne linearne kombinacije čestica koje čine tu skalu.

Statistička pismenost, rezoniranje i razmišljanje su mjereni *Testom statističkog rezoniranja* (SRA) koji sadrži 20 pitanja s višestrukim mogućim odgovorima kojeg su razvili Konold i Garfield kako bi evaluirali novi kurikulum u Američkim srednjim školama (Garfield, 2003). Svaka čestica u testu predstavlja statistički problem i nudi između četiri i osam odgovora. Gotovo svako pitanje ima jedan odgovor koji predstavlja točno rezoniranje i ostale odgovore koji predstavljaju zablude u statističkom rezoniranju. U tablici 3 nalazi se popis subskala čiji su rezultati korišteni u ovom istraživanju. Test ima zadovoljavajuću test-retest pouzdanost, ali nisku pouzdanost tipa unutarnje konzistencije što ukazuje na to da skale vjerojatno ne mjere jednu sposobnost (Garfield, 2003). Primjer pitanja:

„Jednu polovicu novorođene djece čine djevojčice, a drugu dječaci. U bolnici A imaju u prosjeku 50 rođenih dnevno, dok bolnica B bilježi prosjek od 10 rođenih dnevno. Koja bolnica ima veću vjerojatnost imati 80% novorođenih curica u jednom danu?

a) Bolnica A (s 50 rođenja dnevno).

- b) *Bolnica B (s 10 rođenja dnevno).*
- c) *Obje bolnice imaju jednaku vjerojatnost zabilježiti takav događaj.“*

*Tablica 3*  
Prikaz subskala na testu statističkog rezoniranja (Garfieldu, 2003)

Subskala	Objašnjenje
Interpretacija vjerojatnosti	<i>Točno interpretiranje vjerojatnosti.</i> Ispituje razumijevanje vjerojatnosti i donošenja odluka o ishodima događaja na temelju vjerojatnosti.
Središnja vrijednost	<i>Odabir primjerene mjere središnje vrijednosti.</i>
Računanje vjerojatnosti	<i>Točno računanje vjerojatnosti.</i> Ispituje znanje studenata o tome jesu li svi događaji jednako vjerojatni te znaju li izračunati njihovu vjerojatnost.
Neovisnost događaja	<i>Razumijevanje neovisnosti događaja.</i>
Variranje rezultata	<i>Razumijevanje variranja rezultata uzorka.</i>
Korelacija	<i>Razlikovanje između korelacije i uzročno-posljedične veze.</i>
2x2 tablica	<i>Točno interpretiranje 2x2 tablice.</i> Ispituje znanje o interpretaciji odnosa između dvije varijable.
Veličina uzorka	<i>Razumijevanje važnosti velikih uzorka.</i>

Na kraju su se nalazila i pitanja o demografskim karakteristikama studenata, a ona su uključivala: spol, dob, broj sati matematike u svakom razredu srednje škole, samoprocjena znanja matematike, prosjek ocjena na studiju i ocjenu iz statistike. Dodano je i pitanje o bihevioralnim namjerama koje je glasilo: *Kolika je vjerojatnost da ćete upisati izborni kolegij koji ima veze sa statistikom?* Sudionici istraživanja su na njega odgovarali koristeći Likertovu skalu sa sedam uporišnih točaka.



## Rezultati

Podaci su obrađeni računalnim programom SPSS verzija 20.0. Prvo je provedena deskriptivna analiza Upitnika stavova prema statistici (SATS), a zatim i korelacije među subskalama (Tablice 4 i 5)

*Tablica 4*  
Deskriptivni podaci SATS upitnika ( $N=144$ )

	<i>M</i> cijelog uzorka ( <i>SE</i> )	<i>M</i> studenata psihologije ( $n=84$ )	<i>M</i> studenata sociologije ( $n=24$ )	<i>M</i> studenata geografije ( $n=35$ )	Cronbahov alfa	Shapiro- Wilk
Afekt	4.38 (0.09)	4.54	4.29	4.03	.79	.98
Kognitivna kompetentnost	5.36 (0.09)	5.56	4.96	5.14	.81	.95*
Vrijednost	4.94 (0.07)	5.03	5.08	4.63	.78	.98
Težina	3.80 (0.06)	3.76	3.80	3.89	.61	.99
Interes	4.92 (0.10)	5.10	5.12	4.38	.82	.96*
Trud	5.11 (0.10)	5.44	4.57	4.69	.77	.95*

*Legenda:* \* =  $p < .05$ ; SE = standardna pogreška aritmetičke sredine

U tablici 4 se može vidjeti kako su studenti na većini subskala postigli rezultat iznad središnje vrijednosti 4, uz iznimku subskale težine na kojoj su postigli rezultat ispod te vrijednosti. Sve subskale su napravljene tako da viša vrijednost predstavlja pozitivniji stav. Konkretnije, veći rezultat na subskali *težine* označava da je studentima statistika lakši predmet. Prema Shapiro-Wilku rezultati na subskalama *afekta*, *vrijednosti* i *težine* ne razlikuju se značajno od normalne distribucije, dok se rezultati na subskalama *kognitivne kompetentnosti*, *interesa* i *truda* razlikuju značajno zbog čega je dodatno pogledana njihova distribucija vizualnim pregledom te su zbog minimalnog odstupanja korištene parametrijske mjere.

*Tablica 5*  
Prikaz korelacija između skala na Upitniku stavova prema statistici (N=144)

	1.	2.	3.	4.	5.	6.
1. Afekt	1	.76**	.45**	.44**	.41**	.20*
2. Kognitivna kompetentnost		1	.26**	.46**	.16	.15
3. Vrijednost			1	.08	.70**	.14
4. Težina				1	-.08	-.26**
5. Interes					1	.33**
6. Trud						1

*Legenda:* \*\* =  $p < .01$ ; \* =  $p < .05$

Nakon analize SATS upitnika je provedena deskriptivna analiza SRA testa. U tablici 6 se mogu vidjeti rezultati te analize te usporedba odgovora hrvatskih studenata sa stranim istraživanjima. Konkretno, rezultati su uspoređeni s uzorkom nizozemskih (Tempelaar, 2004), američkih i tajvanskih studenta (Garfield, 2003) za koje postoje samo rezultati o proporciji točnih odgovora zbog čega nije bilo moguće usporediti značajnost razlika.

*Tablica 6*  
Rezultati SRA testa izraženih kao proporcija točnih odgovora te usporedba s rezultatima drugih istraživanja (N=144)

Subskale	hrvatski studenti (SE)	nizozemski studenti (N=1303)	američki studenti (n=245)	tajvanski studenti (n=267)
Interpretacija vjerojatnosti	0.78 (0.023)	0.69	0.68	0.68
Središnja vrijednost	0.50 (0.021)	0.71	0.61	0.60
Računanje vjerojatnosti	0.31 (0.019)	0.41	0.45	0.46
Neovisnost događaja	0.53 (0.024)	0.60	0.63	0.74
Variranje rezultata	0.26 (0.023)	0.25	0.22	0.23
Korelacija	0.76 (0.035)	0.70	0.52	0.65
2x2 tablica	0.45 (0.041)	0.77	0.65	0.79
Veličina uzorka	0.55 (0.029)	0.72	0.68	0.76
Točno rezoniranje	0.52 (0.010)	0.58	0.56	0.60

*Legenda:* SE = standardna pogreška proporcije

Prema tablici 6 u ovom istraživanju studenti su postigli najlošiji rezultat na subskali *variranja rezultata* te je takav rezultat u skladu s ostalim istraživanjima. Najbolje rezultate su studenti

postigli na subskalama *interpretiranja vjerojatnosti* i *razlikovanja korelacije i uzročno-posljedične veze*. Također je provedena i korelacijska analiza između subskala testa statističkog rezoniranja i ocjene iz statistike (tablica 7).

*Tablica 7*  
Korelacije između subskala testa statističkog rezoniranja i ocjene iz statistike (N=144)

	1.	2.	3.	4.	5.	6.	7.	8.	9.
1. Interpretacija vjerojatnosti	1	.05	.04	.10	.05	.08	.03	.18*	-.19*
2. Središnja vrijednost		1	-.00	-.01	-.07	-.02	.11	.02	.04
3. Računanje vjerojatnosti			1	-.43**	.13	-.18*	.03	.09	.13
4. Neovisnost događaja				1	-.15	.01	-.04	-.12	-.13
5. Variranje rezultata					1	.16	.07	-.02	.01
6. Korelacija						1	-.04	.01	.04
7. 2x2 tablica							1	.01	.05
8. Veličina uzorka								1	-.09
9. Ocjena iz statistike									1

*Legenda:* \* =  $p < .05$ ; \*\* =  $p < .01$

Većina dobivenih korelacija nije značajna, a jedina značajna korelacija s ocjenom iz statistike je negativna. Takav nalaz ukazuje na to da se radi o složenom konstrukt koji mjeri stvari koje nisu povezane s ocjenom iz statistike.

Kako bi se odgovorilo na prvi istraživački problem korištena je multivarijatna analiza varijance. Prvi problem želi ispitati razlike u stavovima prema statistici obzirom na spol i studijsku grupu (psihologija, geografija i sociologija).

Kako bi se provela multivarijatna analiza varijance najprije su provjereni uvjeti za provedbu analize. Pogledane su distribucije varijabli te je proveden Boxov test jednakosti kovarijanci koji se nije pokazao značajnim. Nakon toga je provedena multivarijatna analiza varijance (2x3, spol (muški, ženski) x smjer (psihologija, geografija, sociologija)) sa subskalama upitnika stavova prema statistici kao zavisnim varijablama.


Provedena multivarijatna analiza varijance pokazala je značajne razlike između grupa. Točnije, koristeći *Pillai's Trace*, dobivena je značajna razlika između različitih smjerova na fakultetu ( $V=0.18$ ,  $F(12/250)=2.07$ ,  $p=.02$ ), značajna razlika na varijabli spola ( $V=0.18$ ,

$F(6/124)=4.43$ ,  $p<.001$ ) te značajan efekt interakcije ( $V=0.17$ ,  $F(12/250)=1.91$ ,  $p=.03$ ). Zbog dobivenog interakcijskog efekta studenti su svrstani u 6 kategorija: psiholozi, geografi, sociolozi, psihologice, sociologinje i geografkinje. Na tih šest kategorija provedena je kanonička diskriminacijska analiza, a dobivene su dvije značajne funkcije (Funkcija 1 – Wilkova Lambda=0.53, Hi-kvadrat(30)=81.36,  $p<.001$ , Funkcija 2 – Wilkova Lambda=0.74, Hi-kvadrat(20)=38.67,  $p=.007$ ) čiji karakteristični korijeni zajedno objašnjavaju 87.2% varijance ukupne diskriminacijske snage. U tablici 8 je prikazana matrica strukture dobivenih funkcija kako bismo odredili njihov teorijski značaj.

*Tablica 8*  
Prikaz matrice strukture nakon provedene kanoničke diskriminacijske analize ( $N=144$ )

SATS	Funkcija 1	Funkcija 2
Trud	0.95	-0.12
Afekt	0.15	0.79
Kognitivna kompetentnost	0.21	0.79
Interes	0.39	0.42
Vrijednost	0.14	0.55
Težina	-0.30	0.23

U tablici 8 nalaze se rezultati koji pokazuju da prva funkcija visoko korelira sa skalom *truda*, a druga funkcija sa skalama *afekta*, *kognitivne kompetentnosti*, *interesa* i *vrijednosti*. Prikaz položaja pojedinih grupa na funkcijama nalazi se na slici 2. Matrica strukture nam pokazuje kako skala *težine* najlošije razlikuje ove grupe studenata.



Slika 2: Prikaz centroida grupa na dobivenim funkcijama u kanoničkoj diskriminacijskoj analizi

Na slici 2 vide se rezultati pojedinih grupa u koordinatnom sustavu sastavljenom od dvije funkcije dobivene u kanoničkoj diskriminacijskoj analizi. Na funkciji 1, koja predstavlja *trud*, ističe se rezultat psihologica s vrijednošću 0.7, dok se rezultati svih ostalih grupa nalaze između vrijednosti -0.4 i -0.6. Rezultati na funkciji 2, koja predstavlja *afekt, kognitivnu kompetentnost i vrijednost*, ukazuju na to da studenti na njoj postižu više rezultate nego studentice. Diskriminacijska analiza povećava vjerojatnost svrstavanja u pravu grupu s 16.7% na 45.9%, to znači da se na temelju podataka na ovom upitniku nešto manje od polovice studenata može točno svrstati obzirom na njihov spol i studijsku grupu.

Kako bi se odgovorilo na drugi i treći problem korištena je hijerarhijska regresijska analiza. Drugi i treći problem žele ispitati mogućnost predviđanja statističkog rezoniranja (drugi problem) i namjere upisivanja statističkih kolegija (treći problem) na temelju studentskih karakteristika, prijašnjih iskustava i stavova prema statistici.

U prilogu 1 nalazi se korelacijska matrica varijabli uključenih u regresijske analize. U provedenim hijerarhijskim regresijskim analizama su u prvom koraku uključene su varijable

spola (kao varijable iz kategorije studentskih karakteristika), samoprocjene znanja srednjoškolske matematike i prosječnog broja sati matematike u srednjoj školi (kao mjere prijašnjih iskustava), a u drugom mjere stavova prema statistici (ljestvice: *afekt*, *trud*, *vrijednosti*, *kognitivna kompetencija*, *težina* i *interes*). Rezultati dobiveni hijerarhijskim regresijskim analizama nalaze se u tablici 9.

Tablica 9

Rezultati hijerarhijske regresijske analize s kriterijem ljestvice točnog rezoniranja i kriterijem namjere upisivanja izbornih kolegija koji imaju veze sa statistikom.

	SRA	Namjera
	$\beta$	$\beta$
Model 1		
Spol	-.27**	-.09
Znanje matematike	.09	.30**
Prosjeak sati matematike u s.š.	-.02	-.10
Model 2		
Spol	-.26*	.02
Znanje matematike	.08	.15
Prosjeak sati matematike u s.š.	-.03	-.06
Afekt	.00	.22
Kognitivna kompetentnost	.05	.14
Vrijednost	.02	.29**
Težina	.02	-.10
Interes	.01	.12
Trud	.01	-.06
Model 1		
$R^2$	.08	.09
korigirani $R^2$	.06	.07
$F$	3.77	4.29
$p$	.01	.006
Model 2		
$R^2$ ( $R^2_{adj}$ )	.09 (.03)	.39 (.35)
$F$	1.37	8.83
$p$	.21	.001
$\Delta R^2$	.01	.30
$F_{\Delta R^2}$	0.24	10.19
$p_{\Delta R^2}$	.96	.001

*Legenda:*  $\beta$  = vrijednost standardiziranog regresijskog koeficijenta;  $R^2_{adj}$  = korigirani ukupni doprinos objašnjenjanoj varijanci;  $F$  = vrijednost ukupnog  $F$ -omjera;  $\Delta R^2$  = doprinos pojedine grupe prediktora objašnjenjanoj varijanci;  $F_{\Delta R^2}$  = vrijednost  $F$ -omjera za dodanu grupu prediktora; s.š. = srednja škola; \* =  $p < .05$ ; \*\* =  $p < .01$ ; SRA = ljestvica točnog rezoniranja; Namjera = namjera upisivanja izbornog kolegija koji ima veze sa statistikom

Kod prvog istraživačkog problema u prvom koraku kao jedini značajni prediktor izdvojio se spol ( $Beta = -.27$ ,  $t = -3.12$ ,  $p < .01$ ) u smjeru da studenti postižu više rezultate od studentica. U drugom koraku nije dobiveno značajno povećanje objašnjenja varijance kriterija. Odnosno uvođenje stavova prema statistici ne doprinosi dodatnom objašnjavanju varijance rezultata na SRA testu.

U trećem istraživačkom problemu kriterij je bio namjera upisivanja izbornih kolegija koji imaju veze sa statistikom, a prediktori su ostali isti kao u prethodnoj regresijskoj analizi. U tablici 9 vidi se da ova regresijska jednadžba objašnjava 39% varijance namjere upisivanja izbornog kolegija koji ima veze sa statistikom. U drugom koraku dobiveno je značajno povećanje objašnjenja varijance kriterija ( $\Delta R^2 = 0.30$ ,  $\Delta F(6/124) = 10.19$ ,  $p < .01$ ). U prvom koraku je *samoprocjena znanja matematike* imala značajan ponder ( $Beta = .30$ ,  $t = 3.48$ ,  $p < .01$ ) međutim dodavanjem subskala stava u drugom koraku ona gubi svoju značajnost, a u drugom koraku jedino skala *vrijednosti* ima značajan ponder.

## Rasprava

U ovom istraživanju cilj je bio utvrditi razlike u stavovima prema statistici studentica i studenata različitih usmjerenja, kao i utvrditi prediktore uspješnog statističkog rezoniranja i bihevioralnih namjera korištenja statistike u budućnosti. Pozitivni stavovi prema statistici su važni kako bi studenti koji su usvojili osnovna statistička znanja i načine razmišljanja bili ohrabreni ta znanja koristiti u daljnjem obrazovanju i poslu. Zbog toga Garfield i suradnici (2002) navode kako bi studenti nakon uvodnog kolegija iz statistike trebali vjerovati da mogu razumjeti i koristiti statistiku, da će im ona biti korisna u životu te da je zanimljiva.

Rezultati ovog istraživanja pokazuju da studenti prvih godina psihologije, geografije i sociologije u prosjeku imaju pozitivne stavove prema statistici. To je vidljivo u tablici 4 koja pokazuje rezultate hrvatskih studenata koji na skalama *afekta*, *kognitivne kompetencije*, *vrijednosti*, *interesa* i *truda* postižu vrijednosti veće od središnje vrijednosti skale. Ovakvi rezultati ukazuju na to kako uvjerenje da studenti imaju negativne stavove prema statistici nije istinito. Jedina skala stavova prema statistici na kojoj su studenti postigli rezultat ispod središnje vrijednosti je skala *težine*. To znači da većina studenata smatra kako je statistika

težak kolegij. Za lakše razumijevanje bitno je naglasiti kako sam naziv skale *težina* navodi na krivi trag jer su sve skale kodirane tako da veće vrijednosti pokazuju pozitivniji stav, odnosno viši rezultat na skali *težine* znači da je studentu predmet bio lakši. Takvi rezultati su donekle iznenađujući jer se studenti smatraju kognitivno kompetentnima naučiti statistiku, a istovremeno smatraju da je statistika donekle težak predmet. Ovaj nalaz je u skladu s prijašnjim istraživanjima prema kojima neki ljudi smatraju statističko razmišljanje teškim (Kahneman i Tversky, 1982). Percepcija težine statističkih kolegija kod dijela studenata može se pripisati i činjenici da ona zahtjeva i apstraktnija razmišljanja (Sfrad, 2000). To je posebno bitno kada se statistika uspoređuje s drugim kolegijima za koje najčešće nije nužno usvojiti takav novi apstraktni način razmišljanja. U skladu s tim, Baloglu (2003) smatra da neki studenti doživljavaju statistiku teškom zbog straha od statistike, a ne zbog nedostatka sposobnosti.

Kako bi se utvrdila razlika u stavovima prema statistici između studenata različitih studijskih grupa i različitog spola provedena je multivarijatna analiza varijance. Provedena analiza, u skladu s hipotezom, pokazala je oba značajna glavna efekta. Međutim dobiven je i interakcijski efekt između spola i pripadnosti grupe, što nije bilo u skladu s hipotezom zbog čega je provedena kanonička diskriminacijska analiza sa studentima svrstanim u šest grupa. Analiza je pokazala da se studenti razlikuju na dvije funkcije od kojih jedna predstavlja *trud*, a druga kombinaciju *afekta*, *kognitivne kompetentnosti* i *vrijednosti*. Te funkcije točno razvrstavaju oko 45% studenata. Na drugoj funkciji ističe se razlika između studenata i studentica i to u smjeru da se studenti nalaze više na toj funkciji. Takav nalaz je u skladu s dijelom prethodnih istraživanja (Ramirez i sur., 2012). Rezultati kanoničke diskriminacijske analize ukazuju na to da studentice psihologije ulažu više truda od svih ostalih studenata uključenih u istraživanje. Takav rezultat može se objasniti time da, kao što je pokazala i ova diskriminacijska analiza, one smatraju da je statistika vrijednija nego ostale studentice. Nasuprot tome, na funkciji 2, koja je kombinaciju *afekta*, *kognitivne kompetentnosti* i *vrijednosti*, postižu rezultate niže od studenta. Na temelju svega navedenog može se zaključiti da studentice psihologije svojim trudom žele nadomjestiti svoj percipirani nedostatak kompetentnosti u savladavanju statistike. Takvi rezultati, također, se mogu



pripisati činjenici da su u trenutku provođenja istraživanja sve studentice psihologije položile kolegij iz statistike, čime su dobili svojevrsnu povratnu informaciju o svojoj kompetentnosti, ali su morale uložiti i više truda nego studentice i studenti ostalih studija. Za razliku od njih nisu svi studenti geografije i sociologije dobili službeni dokaz o vlastitom uspjehu o statistici, odnosno konačnu prolaznu ocjenu, a postižu i veću prosječnu ocjenu od studenata psihologije. Takav nalaz je u skladu s modelom stavova prema statistici koji kaže da ishodi statističkih kolegija s vremenom utječu na stavove prema statistici (Schau, 2003).

Stavovi prema statistici međusobno su povezani što je pokazano u tablici 5. Studenti koji imaju pozitivnije osjećaje prema statistici pokazivat će veći interes prema statistici, ulagat će više truda, smatrat će se kompetentnijima te će smatrati da je statistika lakša. Studenti koji smatraju da je statistika korisna za budućnost pokazivat će više interesa prema statistici, dok će studenti koji percipiraju statistiku težom ulagati više truda. Takvi nalazi su u skladu s prethodnim istraživanjima te pokazuju važnost ukazivanja na vrijednost statistike i stvaranja pozitivnih osjećaja prema statistici nakon odslušanih statističkih kolegija (Schau i sur., 1995).

Uz utvrđivanje stavova prema statistici ispitano je koliko su studenti uspješni u testu statističkog rezoniranja (SRA). Kao što je već navedeno SRA osim statističkog rezoniranja mjeri i statističku pismenost i razmišljanje, a svi se smatraju univerzalnim ishodima na statističkim kolegijima (Garfield i sur., 2002). Najlošiji rezultat hrvatski studenti su postigli na razumijevanju raspršenja rezultata, međutim takav rezultat je u skladu s ostalim istraživanjima. Ta subskala ispituje razumijevanje interpretacije razlika između grupa s obzirom na prosječnu vrijednost i mjere raspršenja. Tempelaar (2004) smatra da je to posljedica nejasne slike jednog od pitanja unutar te subskale. Subskale računanja vjerojatnosti i razumijevanja neovisnosti također su predstavljale problem hrvatskim studentima. Obje subskale ispituju poznavanje osnova teorije vjerojatnosti, a međusobno su umjereno visoko negativno povezane. Takva korelacija ukazuje na to da dio studenata smatra da su svi obrasci pojave određenih događaja jednako vjerojatni (poput uzastopnog bacanja kocke), a dio studenata smatra da su svi ti obrasci različito vjerojatni (poput bacanja novčića pet puta zaredom) neovisno o stvarnoj vjerojatnosti.

Budući da su prijašnja istraživanja pokazala kako studenti različitih država postižu različit uspjeh na testu statističkog rezoniranja dodatno su analizirani podaci ovog istraživanja u odnosu na inozemne nalaze. Preuzeti su rezultati iz istraživanja koja su mjerila statističko rezoniranje kod nizozemskih, američkih i tajvanskih studenata (Tempelaar, 2004; Garfield, 2002). Usporedba na razini trenda nalaza ovog i navedenih stranih istraživanja temelji se isključivo na temelju uvida u prosječne rezultate na pojedinim subskalama bez uvida u mjere raspršenja. Zbog navedenog se u sljedećim zaključcima govori samo o smjerovima razlika, dok je stvarne razlike potrebno utvrditi novim istraživanjem. Smjer rezultata na pojedinim subskalama ukazuje na to da hrvatski studenti postižu nešto viši rezultat na subskali točne interpretacije vjerojatnosti i na subskali razlikovanja korelacije i uzročnosti, dok su na ostalim subskalama postigli niže rezultate. Čini se da najveća razlika postoji na subskali interpretacije 2x2 tablice, koja je u ostalim državama imala veliku proporciju točnih odgovora, a kod hrvatskih studenata je u prosjeku točno odgovorilo manje od polovice studenata.

Razlike u rezultatima između pojedinih država najvjerojatnije su posljedica razlika u sustavima obrazovanja. Sam SRA instrument osmišljen je kao evaluacija srednjoškolske statistike, a u hrvatskom sustavu ne postoji statistika u srednjim školama.

Kako bi se utvrdilo koji su prediktori uspjeha na Testu statističkog rezoniranja provedena je hijerarhijska regresijska analiza. U nju su najprije ubačeni sljedeći prediktori: spol (kao varijable iz kategorije studentskih karakteristika), samoprocjene znanja srednjoškolske matematike i prosječnog broja sati matematike u srednjoj školi (kao mjera prijašnjih iskustava), a zatim mjere stavova prema statistici u drugom koraku. Kao jedini značajan prediktor izdvojio se spol u smjeru da studenti postižu više rezultate od studentica. Takva regresijska jednadžba objašnjava oko 8% varijance kriterija. Razlike u statističkom rezoniranju između studenata i studentica pronađene su i u drugim istraživanjima (Ramirez i sur., 2012). Teško je odrediti razloge zbog kojih dolazi do razlika između studenata i studentica. Jedan od mogućih razloga je razlika u znanju matematike koja se pronalazi u međunarodnim istraživanjima obrazovanja (OECD, 2016). Međutim, samo znanje matematike nije prediktor učinka na SRA testu, zbog čega je potrebno dodatno istražiti

uzroke razlika između studenata i studentica. Prema modelu stavova prema statistici (SATS-M, Schau, 2003) prijašnja iskustva u sličnim područjima utječu na ishode statističkih kolegija, što u ovom istraživanju nije potvrđeno. U hijerarhijskoj regresijskoj analizi, sa skalom točnog rezoniranja kao kriterijem, samoprocjena znanja matematike u srednjoj školi, kao ni broj sati matematike, nisu se pokazali značajnima. Međutim, takav rezultat je donekle u skladu s prethodnim istraživanjima koja su na velikim uzorcima ( $N=1303$ , Tempelaar, 2004) dobivala tek male korelacije između prethodnog iskustva i uspjeha na SRA testu. Prema prvoj hipotezi, osim spola i prethodnog iskustva u sličnim područjima na uspjeh u SRA testu trebali su utjecati i stavovi prema statistici. Međutim, drugi korak hijerarhijske regresijske analize, u kojem su uključeni stavovi prema statistici, nije doveo do značajnog povećanja objašnjenja statističkog rezoniranja. Na temelju svega može se zaključiti kako su statistička pismenost, rezoniranje i razmišljanje složeni konstrukti čije je faktore potrebno dodatno istražiti te kako je najprije potrebno napraviti test koji će razdvajati statističku pismenost, rezoniranje i razmišljanje. Osim toga, na statističku pismenost, rezoniranje i razmišljanje vjerojatno utječu i neki konstrukti koji nisu uključeni u ovo istraživanje što je potrebno dodatno istražiti kako bi se znanje statistike što učinkovitije moglo prenijeti na studente.

Prema SATS-M osim stavova prema statistici i statističke pismenosti, rezoniranja i razmišljanja, nakon odslušanih obaveznih kolegija, također je bitno hoće li se studenti nastaviti dodatno obrazovati o statistici i izvan obavezne nastave iz statistike. U provedenoj hijerarhijskoj regresijskoj analizi u prvom koraku se samoprocjena znanja matematike (kao mjera prethodnog iskustva) pokazala kao značajan prediktor, međutim u drugom koraku ona gubi značajnost, a u drugom koraku kao jedini značajan prediktor se izdvojila skala *vrijednosti* u predviđanju toga hoće li studenti upisati izborne kolegije koji imaju veze sa statistikom. Takav nalaz je u skladu s modelom stavova prema statistici koji predviđa da je stav prema statistici medijator veze između prethodnih iskustva sa sličnim područjima i ishoda statističkih kolegija. Može se zaključiti kako je kod studenata posebno važno poticati vrijednost i korisnost statistike za buduće poslove kako bi se oni što više dodatno obrazovali u ovom području. Ovi nalazi donekle su sukladni onima dobivenim u prijašnjim

istraživanjima te pokazuju kako različiti faktori određuju različite ishode statističkih kolegija. Potvrđena je važnost ukazivanja na vrijednost statistike kako bi se studenti nastavili pohađati kolegije koji imaju veze sa statistikom na temelju čega proizlaze i neke bitne implikacije.

Teorijska implikacija ovog istraživanja je pružanje dodatnog dokaza u prilog Ecclesinoj teoriji očekivanja i vrijednosti. Do sada su mnoga istraživanja u različitim granama obrazovanja pokazala valjanost Ecclesine teorije u predviđanju obrazovnih i nekih drugih ishoda (Ramirez i sur., 2012). Teorija, a i ovo istraživanje, nam pokazuju da studentski stavovi značajno utječu na njihove obrazovne ishode i ponašanja. Iako većina nas vjeruje da su stavovi prema statistici bitni, provedeno je malo istraživanja koja bi takav nalaz potvrdila. Teorijska podloga je iznimno bitna i za praksu kako bi se predavanja mogla što više standardizirati u svrhu kvalitetnijeg usvajanja znanja. Statistički kolegiji bi trebali sadržavati prave poslovne probleme, kako bi studenti vidjeli korist statistike u svom budućem poslu. Na primjer, studenti bi trebali imati zadatak odrediti vjerojatnost da pojedine osobe odu iz organizacije.

Ovo istraživanje pokazuje kako bi bilo poželjno kada bi profesori radili na stavovima svojih studenata od samog početka te im pokazali da statistika ne mora biti teška iako im je matematika bila. U suprotnom se često događa da studenti kažu kako im matematika *ne ide* te zbog toga odustanu od učenja statistike već u samom početku. To je velik problem za njih same, ali i za znanost općenito jer su upravo statistika i metodologija ono što često čini razliku između psihologa kao stručnjaka i laika koji zna puno o psihologiji.

### **Metodološka ograničenja i smjernice za buduća istraživanja**

Premda osmišljeno kako bi dalo odgovor na pitanja koja su proizašla iz opaženih nedostataka drugih istraživanja, i ovo istraživanje ima nekoliko nedostataka. Najvažnije ograničenje ovog istraživanja odnosi se na veličinu uzorka. Naime, broj sudionika ovog istraživanja je ograničen brojem studenata na pojedinim studijskim grupama. Nadalje, svi studenti psihologije koji su sudjelovali u istraživanju su položili obavezni kolegij iz statistike, dok je kod studenta sociologije bilo i studenata koji su samo odslušali kolegij, ali ga nisu položili, a kod studenata geografije nitko od studenata nije dobio završnu ocjenu iz statistike jer je

kod njih statistika godišnji, a ne semestralni predmet. Takve razlike mogle su utjecati na rezultate istraživanja u skladu s teorijom SATS-M. Sljedeće ograničenje ovog istraživanja, a koje je važno naglasiti, je način prikupljanja podataka. Naime, podaci su prikupljeni na fakultetu u sklopu obavezne nastave studenata te je moguće da su studenti mislili kako se radi o istraživanju njihovih profesora zbog čega su mogli rezultate prikazati socijalno poželjno. Na kraju, korišteni upitnici prevedeni su za potrebe ovog istraživanja te njihove metrijske karakteristike nisu prethodno provjerene.

Navedena ograničenja ujedno sadržavaju i smjernice za buduća istraživanja. Postojećim podacima trebalo bi pridružiti podatke i ostalih sastavnica Sveučilišta u Zagrebu. Tada bi postojala veća mogućnost generalizacije rezultata na temelju kojih bi se mogli donositi sigurniji zaključci o stavovima prema statistici, statističkom rezoniranju, kao i njihovoj povezanosti. Također, prije toga potrebno je konstruirati upitnik koji bi obuhvatio veću varijancu stava i koji je prilagođen hrvatskom uzorku, kao i test sa širim opsegom gradiva, faktorima u skladu s teorijom i jednostavnijim načinom ocjenjivanja. Ovo istraživanje je rasvijetlilo ovu važnu problematiku, ali je potrebno obuhvatiti i studente na preostalim studijskim smjerovima i godinama kako bi se točno utvrdili prostori za napredak u studijskim programima.

## **Zaključak**

Ovo istraživanje željelo je utvrditi razlike u stavovima prema statistici između studenata i studentica različitih studijskih smjerova. Najprije se utvrdilo kako studenti psihologije, geografije i sociologije sa Sveučilišta u Zagrebu uglavnom imaju stavove prema statistici koji su pozitivni, odnosno njihova prosječna vrijednost se nalazi iznad središnje vrijednosti skale. Također, studenti smatraju kako je statistika težak predmet, odnosno na toj skali postižu rezultat ispod središnje vrijednosti skale. Nakon provedene kanoničke diskriminacijske analize na funkciji koju većinom predstavlja skala *truda* studentice psihologije su se izdvojile kao one koje ulažu najviše truda. Na funkciji 2 koja se sastoji od *afekta*, *kognitivne kompetentnosti* i *vrijednosti* uočljiva je razlika između studenata i studentica i to tako da se muškarci nalaze više od žena na toj funkciji. Također je ispitana

povezanost individualnih karakteristika studenata, njihovih prijašnjih iskustava i stavova prema statistici sa statističkim rezoniranjem i bihevioralnim namjerama za buduće bavljenje statistikom. Regresijska jednadžba objašnjava 8% varijance statističkog rezoniranja, a kao jedini značajan prediktor izdvojio se spol. Kao jedini značajni prediktor namjere upisivanja izbornog kolegija koji ima veze sa statistikom izdvojila se *vrijednost*, a ona objašnjava 39% varijance.

Rezultati ovog istraživanja ukazuju na potrebu za radom na poboljšavanju stavova prema statistici kako bi studenti češće koristili statistiku u svojoj akademskoj i poslovnoj budućnosti. Posebno je važno naglašavati praktičnu vrijednost statistike te razvijati interes prema statistici kod studenata kako bi se oni češće bavili statistikom. U budućim istraživanjima potrebno je utvrditi stabilnost metrijskih karakteristika prevedenih upitnika ili razviti nove instrumente te na većem uzorku istražiti koji su prediktori uspješnog statističkog rezoniranja kako bi se dobile smjernice koje bi studentima olakšale usvajanje tih znanja i vještina.

## Literatura

- Ajzen i. i Fishbein, M. (1977). Attitude-behavior relations: A theoretical analysis and review of empirical research. *Psychological bulletin*, 84(5), 888-918.
- Anderson, L. W., Krathwohl, D. R., Airasian, P., Cruikshank, K., Mayer, R., Pintrich, P., ... i Wittrock, M. (2001). A taxonomy for learning, teaching and assessing: A revision of Bloom's taxonomy. New York. Longman Publishing. Artz, AF i Armour-Thomas, E.(1992). *Development of a cognitive-metacognitive framework for protocol analysis of mathematical problem solving in small groups. Cognition and Instruction*, 9(2), 137-175.
- Bakker, A. (2004). *Design research in statistics education: On symbolizing and computer tools*. Neobjavljeni doktorski rad. Utrecht.
- Baloğlu, M. (2003). Individual differences in statistics anxiety among college students. *Personality and Individual Differences*, 34(5), 855-865.
- Bandura, A. (1986). The explanatory and predictive scope of self-efficacy theory. *Journal of social and clinical psychology*, 4(3), 359-373.
- Ben-Zvi, D. i Garfield, J. B. (2004). *The challenge of developing statistical literacy, reasoning and thinking*. Dordrecht, The Netherlands: Kluwer Academic Publishers.
- Blumberg, C. J. (2001). Is there life after introductory statistics? Prezentirano na 53rd session of the International Statistical Institute.
- Careercast.com (2017) Jobs Rated Report 2017: Ranking 200 Jobs. Preuzeto 10. studenog 2017 sa: <http://www.careercast.com/jobs-rated/2017-jobs-rated-report>
- Carlson, K. A. i Winquist, J. R. (2011). Evaluating an active learning approach to teaching introductory statistics: A classroom workbook approach. *Journal of Statistics Education*, 19(1), 1-23.
- Furnham, A., & Chamorro-Premuzic, T. (2004). Personality and intelligence as predictors of statistics examination grades. *Personality and individual differences*, 37(5), 943-955.
- Chiesi, F. i Primi, C. (2010). Cognitive and non-cognitive factors related to students' statistics achievement. *Statistics Education Research Journal*, 9(1), 6-26.
- Deci, E. L. i Ryan, R. M. (2010). *Self- determination*. John Wiley i Sons inc.
- Emmioğlu, E. i Çapa-Aydın, Y. (2011). A meta-analysis on students' attitudes toward Statistics. Prezentirano na: *58th World Statistics Congress of International Statistical Intitute, Dublin ireland*.

- Evans, B. (2007). Student attitudes, conceptions, and achievement in introductory undergraduate college statistics. *The Mathematics Educator*, 17(2), 24-30.
- Garfield, J. (2003). Assessing statistical reasoning. *Statistics Education Research Journal*, 1, 22-38.
- Garfield, J. i Ben-Zvi, D. (2008). *Developing students' statistical reasoning: Connecting research and teaching practice*. Springer Science i Business Media.
- Garfield, J., Chance, B. i Snell, J. L. (2001). Technology in college statistics courses. In *The teaching and Learning of Mathematics at University Level*. Springer Netherlands. 357-370.
- Garfield, J., delMas, R. i Chance, B. (2003). The Web-based ARTIST: Assessment resource tools for improving statistical thinking. Prezentirano na: *annual meeting of the American Educational Research Association, Chicago*.
- Garfield, J., Hogg, B., Schau, C. i Whittinghill, D. (2002). First courses in statistical science: The status of educational reform efforts. *Journal of Statistics Education*, 10(2), 456-467.
- Guenole, N., Ferrar, J., Feinzig, S. (2017). *The power of people*. Pearson education inc.
- Hair, J. F., Black, W.C., Babin B.J. i Anderson, R.E. (2009). *Multivariate data analysis*. Pearson
- Hewstone, M. i Stroebe, W. (2003). *Socijalna psihologija*. Jastrebarsko: Naklada Slap.
- Kahneman, D. i Tversky, A. (1982). On the study of statistical intuitions. *Cognition*, 11(2), 123-141.
- Konold, C. (1989). Informal conceptions of probability. *Cognition and Instruction*, 6, 59-98.
- Lecoutre, M. P. (1992). Cognitive models and problem spaces in "purely random" situations. *Educational Studies in Mathematics*, 23, 557-568.
- Macher, D., Paechter, M., Papousek i. i Ruggeri, K. (2012). Statistics anxiety, trait anxiety, learning behavior, and academic performance. *European journal of psychology of education*, 27(4), 483-498.
- Mallows, C. (1998). The zeroth problem. *The American Statistician*, 52(1), 1-9.
- OECD (2016). *PISA 2015 Results (Volume I): Excellence and Equity in Education*. OECD Publishing. Paris.
- Petz, B. (2005). *Psiholgijski rječnik*. Jastrebarsko: Naklada Slap



- Petz, B. (2007). *Osnovne statističke metode za nematematičare*. Jastrebarsko: Naklada Slap
- Ramirez, C., Schau, C. i Emmioğlu, E. (2012). The importance of attitudes in statistics education. *Statistics Education Research Journal*, 11(2), 57-71.
- Ruggeri, K., Dempster, M. i Hanna, D. (2011). The Impact of Misunderstanding the Nature of Statistics. *Psychology Teaching Review*, 17(1), 35-40.
- Ruggeri, K., Díaz, C., Kelley, K., Papousek I., Dempster, M. i Hana, D. (2008). International issues in education. *Psychology Teaching Review*, 14(2), 65–74.
- Ruggeri, K. (2011). The Impact of Misunderstanding the Nature of Statistics. *Psychology Teaching Review*, 17(1), 35-40.
- Schau, C. (2003). Students' attitudes: The "other" important outcome in statistics education. In *Proceedings of the joint statistical meetings*. 3673-3681.
- Schau, C., Stevens, J., Dauphinee, T. L. i Vecchio, A. D. (1995). The development and validation of the survey of attitudes toward statistics. *Educational and psychological measurement*, 55(5), 868-875.
- Sfard, A. (2000). On reform movement and the limits of mathematical discourse. *Mathematical thinking and learning*, 2(3), 157-189.
- Tempelaar, D. (2004). Statistical reasoning assessment: An analysis of the SRA instrument. Prezentirano na: *ARTIST Roundtable Conference on Assessment in Statistics*
- Tversky, A. i Kahneman, D. (1974). Judgment under uncertainty: Heuristics and biases. *Utility, probability, and human decision making*. Springer Netherlands. 5(4), 141-162.
- Tversky, A., Slović, P. i Kahneman, D. (1990). The causes of preference reversal. *The American Economic Review*, 80(1) 204-217.
- Van de Vijver, F. i Tanzer, N. K. (2004). Bias and equivalence in cross-cultural assessment: An overview. *European Review of Applied Psychology*, 54(2), 119-135.
- Vizek Vidović, V., Rijavec, M., Vlahović-Štetić, V. i Miljković, D. (2003): *Psihologija obrazovanja iEP - Vern*, Zagreb.
- Wigfield, A. i Eccles, J. S. (2000). Expectancy–value theory of achievement motivation. *Contemporary educational psychology*, 25(1), 68-81.

*Prilog 1*  
Prikaz korelacija između varijabli uključenih u regresijske analize (N=144)

	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	11.
1. Spol studenta	1	-.04	-.06	-.28**	-.19*	-.21*	-.08	-.22**	.07	.33**	-.24**
2. Znanje matematike		1	.26**	.30**	.31**	.47**	.08	.14	.11	.27**	.10
3. Namjera upisivanja kolegija vezanog uz statistiku			1	.001	.520**	.42**	.50**	.11	.46**	.19*	.02
4. Prosjek sati matematike u srednjoj školi				1	.06	.19*	-.02	.14	-.15	-.18*	.06
5. Afekt					1	.76**	.45**	.44**	.41**	.20*	.12
6. Kognitivna kompetentnost						1	.26**	.46**	.16	.15	.13
7. Vrijednost							1	.08	.70**	.14	.12
8. Težina								1	-.08	-.26**	.02
9. Interes									1	.33**	.04
10. Trud										1	-.04
11. SRA											1

*Legenda:* \*\* =  $p < .01$ ; \* =  $p < .05$ ; Spol je kodiran kao M=1, Ž=2